

Jezik znanstvene komunikacije: najčešći konceptualizacijski mehanizmi u opažanju i opisivanju znanstvenih fenomena u informacijskim znanostima

Milijana Mičunović, mmicunov@ffos.hr

Sveučilište J. J. Strossmayera u Osijeku, Filozofski fakultet, Odsjek za informacijske znanosti

Libellarium, IV, 2 (2011): 167 - 187.

UDK: 001.2:007]:81'42

001.2:007]:81'373.612

Izvorni znanstveni rad

Sažetak

Cilj je rada istražiti i predstaviti najčešće konceptualizacijske mehanizme u opažanju i opisivanju znanstvenih fenomena koji omogućuju uspješnu i učinkovitu razmjenu informacija na razini komunikacije između znanstvene zajednice i 'publike', ali i na razini komunikacije unutar same znanstvene zajednice u području informacijskih znanosti.

Primjena konceptualizacijskih mehanizama u jeziku informacijskih znanosti predstavljena je na čestim, gotovo svakodnevno korištenim pojmovima, kao što su baza podataka, *gadget*-utrka, informacijska arhitektura, intelektualno vlasništvo, revolucija tiska, računalni virus, umjetni život i sl. Praćeno je opažanje i opisivanje takvih pojmova kako u popularnom diskursu (primjerice na različitim mrežnim stranicama) tako i u dostupnoj znanstvenoj i stručnoj literaturi.

Rad se sastoji od četiri dijela. Nakon općenitog uvodnog dijela o jeziku znanstvene komunikacije, redom se predstavljaju teorija konceptualne metafore, teorija konceptualne integracije i znanstveni model. Svaki je konceptualizacijski mehanizam popraćen analizom konkretnih primjera iz jezika informacijskih znanosti.

Budući da je područje informacijskih znanosti pod stalnim utjecajem tehnoloških promjena i razvoja suvremene informacijsko-komunikacijske tehnologije, često se uočavaju novi i različiti fenomeni koji traže novi misaoni okvir u procesu opažanja te nove načine jezične artikulacije u procesu njihova opisivanja i komuniciranja znanstvenoj i neznanstvenoj publici. Temeljni je doprinos rada upravo prikaz i analiza nekolicine primjera uočenih novih misaonih okvira i novih načina jezične artikulacije u popularnom i znanstvenom diskursu jezika informacijske znanosti.

KLJUČNE RIJEČI: jezik znanstvene komunikacije, informacijske znanosti, kognitivna lingvistika, konceptualizacija, teorija konceptualne metafore, teorija konceptualne integracije, znanstveni model.

1. Jezik znanstvene komunikacije

Komunikacija u području moderne znanosti započinje pojavom prvih znanstvenih časopisa u Francuskoj i Engleskoj sredinom 17. stoljeća (usp. Stipčević 2006: 477 - 478). Cilj je takve komunikacije bio stvoriti 'javno znanje' odnosno upoznati javnost s racionalnim konsenzusom znanstvenih ideja i informacija objavljujući članke o najnovijim istraživanjima i rezultatima u znanstvenom području iz kojega časopis dolazi. Zbog složenosti i specifičnosti znanstvenih područja te su ideje i informacije često bile nerazumljive i neshvatljive široj javnosti. U suvremenom informacijskom društvu znanstvena je informacija neodvojiva od znanja zajednice, a način na koji je oblikovana i predstavljena javnosti utječe na njezino razumijevanje, učinkovitost/posljedičnost i vrijednost.

U informacijskom društvu odnos znanosti i medija uvelike utječe na razumijevanje znanstvene komunikacije (Peters 2007). Naime gotovo su sva znanstvena istraživanja u ovom području dokazala da se komunikacija znanstvene zajednice s javnošću odvija putem (masovnih) medija, znanstvenih tribina i drugih sličnih skupova te da većinu znanstvenih informacija šira javnost saznaje upravo putem medija (Eurobarometar 2005, 2007; *National Science Foundation Survey* 2008). Najčešći put znanstvenih informacija podrazumijeva njihovo predstavljanje i recenziranje unutar znanstvene zajednice, objavljivanje u znanstvenom časopisu te predstavljanje javnosti putem medija. Radi se o najčešćem, tzv. linearnom modelu znanstvene komunikacije.¹

Jezik suvremene znanosti temelji se na složenom znanstvenom mišljenju. On je na svim razinama i u svim etapama razvoja znanstvenog mišljenja fluidan, fleksibilan, neograničen te omogućuje prijenos značenja. Figurativni izrazi u znanosti mogu se promatrati kao figure uma budući da je metaforički um (metaforička priroda misli) sastavni dio mehanizama koji oblikuju znanstvene teorije. Metaforičko mišljenje i uporaba analogija i modela ključni su za izražavanje apstraktne kategorije vremena, ali i konkretnih kategorija prostora i stanja koje se u suvremenim znanostima, poput informacijskih znanosti, mogu realizirati i na vrlo apstraktne načine (primjerice „virtualni prostor” i „kiberprostor” kao suvremene, apstraktne realizacije kategorije prostora ili „tehnoidentitet” kao bivanje ljudskog i strojnog u istome). Razvojem znanosti i otkrivanjem novih apstraktnih i nepoznatih entiteta, pojava, procesa i struktura raste i uloga figurativne misli i izraza, koji ih prevode na poznati jezik povezujući ih s poznatim iskustvima.

Važan je zadatak svakog znanstvenog jezika omogućiti uspješnu i učinkovitu razmjenu informacija na razini komunikacije između znanstvene zajednice i 'publike', ali i na razini komunikacije unutar same znanstvene zajednice. Naime čak i u uvjetima u

1 Postoji i mrežni model znanstvene komunikacije (Lewenstein 1995) koji uključuje različite čimbenike u proces nastajanja znanstvenih informacija (prijedloge projekata, preprinte, službena izvješća, časopise, medije i dr.).

kojima obje strane komunikacijskog procesa posjeduju znanje o određenom području rijetko se događa da značenje bude preneseno u potpunosti. Upravo tada maštovitost figurativnih izraza i slikovitost metaforičkih koncepata postaju važnim dijelom komunikacije prenoseći značenja koja su dio iskustvenog svijeta sudionika komunikacijskog procesa. Maštovitost i slikovnost izgrađuju kontekst u kojem se povećavaju percepcija, osjetljivost i svjesnost o pojavama, procesima, entitetima i kategorijama koje bi, zbog svoje transcendentnosti, metafizičke prirode i apstraktnosti, inače ostale nezamijećene ili skrivene među detaljima neke složene stvarne situacije.

Kognitivna lingvistika i metaforička prezentacija značenja nisu samo jezične pojave već i mentalni mehanizmi koji omogućuju ljudsku spoznaju – promatranje, percepciju, konceptualiziranje i kategoriziranje. Metafora je integralni dio čovjekova konceptualnog sustava. Ukoliko se radi o opažanju i iskustvu objekta ili događaja čija su svojstva i aspekti bliži i sličniji čovjekovoj okolini, svijetu, tada osjetila, mozak i um ne trebaju velike teorije i 'posrednike', ali ako je u pitanju opažanje nečega što premašuje granice čovjekovih mogućnosti poimanja i razumijevanja svijeta, onda je potrebno angažirati određene instrumente kao što su detaljno razrađene teorije, ali i spekuliranje i eksplicitno pretpostavljanje. Upravo trenutak u kojem osjetila, mozak i um prekoračuju poznate činjenice i podatke, pokušavajući objasniti do tada nepoznate pojave, otvara mjesto metaforičkom jeziku – on je taj koji će pomoći objasniti nepoznati svijet znanosti preoblikujući nejezične slike i modele entiteta i događaja u jezične konstrukcije razumljive čovjekovu razumu i svijesti. Taj put u ne(s)poznato daje izvjesnu romanesknost znanosti kao prostoru koji tek treba otkriti, dok će se prirodni zakoni svijeta i svemira pobrinuti da kontrolom ljudske mašte, intuicije i pretpostavljanja osiguraju znanstvenu objektivnost.

Znanstvena se komunikacija velikim dijelom temelji upravo na metaforičkoj konceptualizaciji. Mnogi autori govore o metaforama kao „jedinicama cirkulacije“ znanja između znanstvenog i javnog društvenog konteksta (Katz 1998; Goatly 2000). Metafora služi poput svojevrsnog nadomjeska, pomagala u situacijama kada se komunicira o apstraktnim, manje opipljivim činjenicama s kojima tijelo ne ulazi u odnos, što je vrlo često u području suvremene znanosti. To je omogućeno povezivanjem apstraktna činjenice s nekim konkretnim pojmom bliskim svakodnevnom iskustvu. Kada se uspostavi motivacijska nit među njihovim sastavnicama, izbor mogućih iskaza pomoću kojih se može neometano komunicirati postaje sve širi. Kako je svijet suvremene znanosti složen od apstraktnih i manje opipljivih činjenica,² metafora se upravo tu može u potpunosti realizirati.

2 Suvremena tehnologija i metodologija otkrivaju sve više nepoznatih i apstraktnih pojava, entiteta i činjenica koje je moguće objasniti tek metaforičkim izrazima, analogijama i modelima.

2. Konceptualna metafora

2.1. Teorija konceptualne metafore

Proces metaforizacije temeljan je za razumijevanje jezika, a metafore se ostvaruju ili kao svjesne jezične strategije ili kao nesvjestan utjecaj društvenog okruženja (Lakoff - Johnson 2003). Priča o metafori počinje još u Aristotelovo vrijeme, kada se ona smatrala tek pasivnom retoričkom figurom čiji je cilj bio izraziti postojeću objektivnu sličnost. Značajnije proširenje značenja metafore i metonimije daje Roman Jakobson u 20. stoljeću. Povezujući ih s paradigmatiskim i sintagmatskim odnosima, Jakobson je metaforu i metonimiju odredio kao dva temeljna postupka u mišljenju i govoru. No tek s razvojem kognitivne lingvistike metafora je postala karakteristika ljudskog procesa mišljenja koja olakšava točnije izražavanje i komuniciranje. Ona više nije samo jezični izraz - ona je metaforički koncept koji se nalazi u ljudskoj svijesti i koji se može izraziti na više načina. Naglasak se sve više stavlja na formativni učinak metafore, a sve manje na njezinu figurativnost. Kognitivna funkcija metafore određuje ju kao sredstvo konceptualizacije, emocionalizacije i vrednovanja.

Teorija konceptualne metafore nastala je 80-ih godina 20. stoljeća u okviru kognitivne lingvistike, a vezana je uz prva istraživanja u tom području (Lakoff - Johnson 1980; Fillmore 1985; Turner 1987; Lakoff - Turner 1989; Lakoff 1993; Gibbs 1994; Kövecses 1986, 1990, 2000, 2002; Grady 1994, 1997; Grady - Oakley - Coulson 1999; Boroditsky 2000 i dr.). Temelji se na Lakoff-Johnsonovu modelu koji podrazumijeva dvodomenski pristup interpretiranja figurativnih iskaza te na mentalnim reprezentacijama iskustva, a predstavlja instrument kojim se izvanjezične pojave pokušavaju objasniti jednostavnim i izravnim uvidom u stvarnost, tj. instrument koji složene domene pojašnjava pomoću jednostavnih domena bližih čovjekovu otjelovljenom iskustvu. Razlika između klasičnog pristupa metafori kao skraćenoj poredbi ili postupku zamjene značenja jedne riječi značenjem druge riječi i konceptualne metafore jest uvođenje druge domene koja će omogućiti preslikavanje, tj. povezivanje pojedinih dijelova domena. To se preslikavanje bilježi 'formulom' CILJNA DOMENA JE IZVORIŠNA DOMENA (A JE B) i ono je uvijek djelomično. Naprimjer izraz „riječ je o velikoj povijesnoj ličnosti“ podrazumijeva konceptualnu metaforu VAŽNO JE VELIKO. Osim preslikavanja s jedne na drugu domenu, važno je na koji način izvorišna domena utječe na razumijevanje i zaključke o ciljnoj domeni. Naprimjer veličina kao kategorija može biti stupnjevana, pa se tako u povijesti mogu pronaći važne, važnije i najvažnije ličnosti određenog vremena i prostora.

Proces preslikavanja između domena podrazumijeva preslikavanje samo središnjeg znanja (Kövecses 2003: 82) izvorišne domene što objašnjava djelomičnost preslikavanja konceptualne metafore. Također, jedna se izvorišna domena može rabiti za objašnjavanje nekoliko različitih ciljnih domena, primjerice izvorišna domena *rat* može objasniti ciljne domene *ljubav* i *argumentirana rasprava*, a izvorišna domena *putovanje* može objasniti ciljne domene *ljubav* i *život* (Lakoff - Johnson 1980; Lakoff

1987). Pojam središnjeg znanja po svojoj je prirodi konvencionaliziran, generičan i karakterističan za pojedinu skupinu entiteta te pripada dijelu enciklopedijskog znanja o određenom konceptu.

Velik dio tih metaforičkih izraza ima izvorišnu domenu u kojoj se mogu identificirati različiti oblici tjelesnog iskustva. Neki su od njih tjelesna aktivnost, percepcijska interakcija s okolinom i objektima u okolini te manipuliranje objektima.³ No kako čovjek razumijeva i predočava apstraktne domene ako o njima ne posjeduje nikakvu iskustvenu informaciju? Autori Gibbs, Lakoff, Johnson, Boroditsky i mnogi drugi objasnili su to činjenicom da je apstraktne domene moguće razumjeti povlačenjem analogije između njih i domena o kojima postoji iskustvena informacija. Analogija se može temeljiti na:

- znanju o apstraktnim domenama koje je tijelo usvojilo kroz osjetilno-motorički sustav i predodžbene sheme i
- znanju o apstraktnim domenama koje se temelje na reprezentacijama iskustvenih domena koje nisu izravno povezane s osjetilno-motoričkim iskustvom.

Veza jezika i tijela sve se više izučava u području kognitivne lingvistike, a najčešće se radi o interdisciplinarnim istraživanjima koja uz kognitivnu lingvistiku uključuju i neurologiju, molekularnu biologiju, psihologiju i druge znanosti. Povezivanje izvorišne i ciljne domene rezultat je i motiviranosti metafore, tj. motiviranosti njezina izvorišnog koncepta. Danas su poznata tri razloga motiviranosti: svođenje kompleksnih konceptualnih metafora na primarne metafore koje su izravno motivirane, motiviranost konceptualnih metafora na temelju središnjih preslikavanja te metonimijska motiviranost konceptualnih metafora (Stanojević 2009: 344). Česti su primjeri konceptualne interakcije metafore i metonimije u kojima metonimija preuzima 'sporedniju' ulogu i smatra se dijelom metafore. Ukupno je poznato šest tipova njihove međusobne interakcije: metonimijsko proširenje izvorišne metaforičke domene, metonimijsko proširenje ciljne metaforičke domene, metonimijsko sužavanje jednog od odgovarajućih dijelova ciljne metaforičke domene, metonimijsko sužavanje jednog od odgovarajućih dijelova izvorišne metaforičke domene, metonimijsko proširenje jednog od odgovarajućih dijelova ciljne metaforičke domene te metonimijsko proširenje jednog od odgovarajućih dijelova izvorišne metaforičke domene.

Ovisno o ustaljenosti povezivanja dviju domena i stupnju pojavljivanja metafore u jezičnim iskazima, može se govoriti o manje ili više konvencionaliziranim metaforama. U prvom slučaju radi se o konvencionaliziranim metaforama koje su postale kolektivnim znanjem određene kulture i nesvjesno se aktiviraju kada je u pitanju određeni jezični iskaz (izraz „izborio se za njezinu ljubav“ utemeljen je na konceptualnoj metafori LJUBAV JE RAT), dok se u drugom slučaju radi o metaforama čija je konvencionaliziranost pitanje jezične, a ne konceptualne razine.

3 Izraz „otjelovljeno iskustvo“ ne mora se uvijek odnositi na tjelesno (fizičko) iskustvo. Postoje brojni primjeri u kojima se otjelovljenost odnosi na kulturno, društveno ili znanstveno iskustvo.

2.2. Konceptualna metafora u jeziku informacijskih znanosti

U posljednje se vrijeme istraživanja u području kognitivne lingvistike temelje na analizi određenih korpusa, tj. upotpunjavanju teorije o metaforičkim konceptima novim primjerima konceptualne metafore. U informacijskim su znanostima takvi primjeri brojni, a većina ih je nastala kao posljedica implementacije suvremene digitalne tehnologije i promjena koje ista uzrokuje u kontekstu informacijskog društva, posebno onoga njegova dijela koji se odnosi na interakciju čovjeka i tehnologije. U primjerima koji slijede opisi određenih fenomena iz područja informacijskih znanosti temelje se na primjeni konceptualne metafore.

Primjer 1. Baza podataka. Pojam predstavlja organiziran skup informacija ili podataka u računalno čitljivom obliku. Unatoč brojnim korisnim informacijama na internetu, pouzdanost i korisnost baza podataka jamči njihova organiziranost, preglednost i visoka relevantnost. Pristup bazama omogućuju različiti mrežni servisi za pretraživanje baza podataka. Korisnicima omogućuju pretraživanje jedne ili više baza prema odabranim ključnim pojmovima (autor, naslov, ključna riječ i dr.), a njihovo je korištenje jedna od nužnih pretpostavki svakog ozbiljnog istraživanja i znanstvenoistraživačkog rada.

Metaforički izraz „baza podataka“ podrazumijeva konceptualnu metaforu **PODTACI SU FIZIČKI OBJEKTI**. Značenjska obilježja fizičkih objekata preslikavaju se na podatke kao apstraktne entete kojima se sada može manipulirati – mogu se pohraniti, organizirati, pretraživati – slično kao i objektima u fizičkom svijetu. Također, u nekim se izrazima baza podataka ‘ponaša’ kao živo biće koje manipulira podacima odnosno obilježja živog razumnog bića kao osobe koja je sposobna vršiti određene fizičke i kognitivne aktivnosti (pohranjivati, organizirati, pretraživati, i analizirati podatke) preslikavaju se na baze podataka. Stoga bi se za te izraze moglo utvrditi da se radi o konceptualnoj metafori **BAZE PODATAKA SU RAZUMNA BIĆA**.

„Compendex **pohranjuje** imena autora u obliku u kojem su navedena u izvor-nicima...

EBSCO **kombinira** rezultate pretraživanja samo putem naprednog pretraživanja...

Medline **pretražuje** podatke uz pomoć tezaurusa MeSH...

Baze podataka **mogu sortirati** po naslovu časopisa, a potom po abecedi prema prezimenu prvog autora“ (Stojanovski 2006).

U ovom su dijelu česti primjeri metonimije koji podupiru tvrdnje Ruiza de Mendoze o metaforičko-metonimijskim odnosima, a o kojima je često pisao u svojim radovima, poput *Cognitive and pragmatic aspects of metonymy* (1996) i *Blended spaces and the pragmatic approach to cognition* (1997). Na primjeru rečenice „EBSCO kombinira rezultate pretraživanja samo putem naprednog pretraživanja“ moguće je identificirati

metonimiju CJELINA ZA DIO u kojoj se EBSCO koristi kao cjelina za one dijelove baze koji se bave naprednim pretraživanjem. U tom bi se slučaju radilo o metonimiji *izvorište u cilju* (engl. *source-in-target*), čiji je cilj istaknuti ili aktivirati ciljnu domenu.

Primjer 2. Gadget-utrka (engl. *gadget race*). *Gadget-utrka* povezana je s porastom kulture konzumerizma i eksplozivnom proizvodnjom *high-tech-gadgeta*.⁴ Kako padaju troškovi proizvodnje i cijena *gadgeta*, raste broj korisnika i kupaca i njihova kupovna moć. Istodobno raste i količina digitalne robe na tržištu. Pojam se odnosi na natjecanje tko će prvi kupiti novi *gadget*. U pozadini tog figurativnog izraza stoji konceptualna metafora KUPOVINA/PRODAJA JE UTRKA. Kao što u svakoj utrci postoje natjecatelji i cilj koji treba dostići u najkraćem mogućem roku, tako i na tržištu *gadgeta* svaki proizvođač/kupac postaje natjecateljem, cilj je prodati/kupiti novi *gadget*, a što manje vremena prođe između izlaska *gadgeta* na tržište i kupovine istog, tim bolje. Na kraju postoji i čimbenik 'slave' – osoba koja je prva kupila *gadget* može se pohvaliti drugima svojim 'uspjehom', slično kao što osoba koja je pobijedila u utrci postaje slavna zbog svog uspjeha:

„Znanstvenici Manhattan projekta **izbijaju na čelo** razvijajući bioničku ruku koja je spojena izravno s mozgom...

Indija bilježi **brzi start** u razvijanju najvećeg svjetskog sustava biometrijske identifikacije...

Prodaja Nintendo DS-a **zaostaje** za prodajom PSP-a. (Nintendo DS i PSP – PlayStation Portable prijenosne su igraće konzole.)

IBM se **pridružio utrci** kreirajući pametnu tehnologiju uz pomoć IBM racionalnih sustava“ (IEEE Xplore Digital Library).

Primjer 3. Informacijska arhitektura. Informacijska arhitektura pojam je koji opisuje strukturu informacijskog sustava kao modele ili koncepte u aktivnostima mrežnog razvoja, bibliotečnih sustava, razvoja baza podataka, programiranja i sl. Ona kategorizira informacije u jasnu i razumljivu strukturu. Pojam podrazumijeva metaforu INFORMACIJSKI SUSTAV JE GRAĐEVINA. Elementi izvorišne domene – planiranje, oblikovanje i gradnja – preslikavaju se na ciljnu domenu. Također, stabilnost građevine preslikava se na stabilnost sustava:

„Informacijska arhitektura zasniva se na **izgradnji** određene infrastrukture u cilju ostvarivanja poslovnih ciljeva“ (Brown 2003).

4 *High-tech-gadgeti* suvremeni su tehnološki proizvodi koji uključuju mobilne uređaje, prijenosna računala, digitalne kamere i fotoaparate, igraće konzole i sl. Njihovu konkurentnost na tržištu održava neprestani razvoj i nadograđivanje samog proizvoda, njegovih mogućnosti i aplikacija.

„Dobra informacijska arhitektura traži dosta **planiranja** i pažljivo **projektiranje** strukture prije samog grupiranja i strukturiranja informacija“ (Reiss 2000).

Tablica 1. Prikaz preslikavanja značenja u metafori INFORMACIJSKI SUSTAV JE GRAĐEVINA

Izvorišna domena: građevina	Ciljna domena: informacijski sustav
građevina	informacijska arhitektura sustava
gradnja	grupiranje i strukturiranje informacija
planiranje	prikupljanje informacija
oblikovanje (projektiranje)	dizajniranje strukture sustava
stabilnost temelja (građevine)	stabilnost sustava

Primjer 4. Inteliktualno vlasništvo. Inteliktualno vlasništvo obuhvaća autorsko pravo i srodna prava te prava industrijskog vlasništva (patente, žigove, industrijski dizajn, oznake zemljopisnog podrijetla i oznake izvornosti, topografiju poluvodičkih proizvoda). Kako se proizvodi ljudskog uma ne mogu zaštititi na način kojim se štite materijalna dobra, bilo je potrebno izumiti mehanizme koji će zaštititi i njihovu vrijednost. Inteliktualno vlasništvo kao figurativni izraz temelji se na konceptualnoj metafori IDEJE SU ROBA. Iz izvorišne se domene na ciljnu preslikavaju obilježja vrijednosti, vlasništva, korištenja, stjecanja materijalne koristi, distribucije i trgovine, ali i obilježja proizvođača koji u domeni ideje jest autor nematerijalnog dobra i njegov vlasnik:

„Proizvodi ljudskog uma predstavljaju **nematerijalna** dobra, čija je vrijednost u **umnožavanju, upotrebi i prikazivanju** drugim ljudima, pa ih nije moguće zaštititi sakrivanjem, zatvaranjem ili drugim mjerama fizičke zaštite...

Pokrali su stihove tuđih pjesama i **iskoristili** ih za svoj novi album...

Neovlaštena uporaba ili umnožavanje predmeta intelektualnog vlasništva predstavlja **povredu** prava“ (Lessig 2004a i 2004b).

Primjer 5. Revolucija tiska. Revolucija tiska jedna je od komunikacijskih revolucija u povijesti ljudskog društva koja je, uz uvođenje promjena u čitanju i čitalačkoj praksi, podjednako utjecala na društvene i vjerske promjene i na razvoj humanističkih i prirodnih znanosti. Njezin početak označuje 1455. godina kada se u Mainzu tiska Gutenbergova *Biblija*. Izraz „revolucija tiska“ podrazumijeva konceptualnu metaforu PROCES TISKANJA JE RAT (ORGANIZIRANI SUKOB):

„Cenzura je bila često **oružje** Crkve **u borbi protiv** tiska nepoćudnih knjiga i sadržaja.“

„Gutenbergovo otkriće tiskarskog stroja **potaknulo je** raznovrsne **promjene** na širem društvenom planu, bolji protok informacija i učinkovitiju komunikaciju.“

„Tisak pomaže širenju novih ideja, te utječe na formiranje javnoga mnijenja u vjerskim i političkim borbama.“ (Stipčević 2006; Pelc 2002).

Tablica 2. prikazuje preslikavanja koja se pritom mogu dogoditi između nekih elemenata izvorišne i ciljne domene.

Tablica 2. Prikaz preslikavanja značenja u metafori PROCES TISKANJA JE RAT (ORGANIZIRANI SUKOB)

Izvorišna domena: rat (organizirani sukob)	Ciljna domena: proces tiskanja
rat	proces tiskanja
revolucija (organizirani ustanak protiv vlasti koji se nekontrolirano širi društvom i mijenja poredak stvari)	revolucija (organizirana aktivnost tiska koja se nekontrolirano širi društvom i unosi promjene u način razmišljanja i širenja informacija i znanja)
borba (za slobodu ideja, nazora, vjere i dr.)	borba (za slobodu tiska)
oružje	cenzura, edikti, progoni, uhićenja
sukobljene strane	tiskari i Crkva
opasnost	opasnost od cenzure, progona, zabrane tiskanja, uhićenja

Primjer 6. Vrednovanje informacija (engl. *information evaluation*). Internet sadrži veliku količinu informacija i ponekad je teško biti siguran u njihovu točnost, objektivnost i relevantnost. Postupkom vrednovanja informacija utvrđuje se i procjenjuje vrijednost, točnost i pouzdanost informacije. Ukoliko je moguće, dobro je napraviti usporedbu nekoliko informacija o istoj temi iz različitih izvora. Figurativni izraz „vrednovanje informacija“ temelji se na konceptualnoj metafori INFORMACIJA JE ROBA. Iz domene robe preslikavaju se obilježja cijene na vrijednost informacije, potražnje robe na relevantnost informacije, kvalitete robe na točnost i provjerenost informacije te mogućnosti kupovine i prodaje robe na komercijalizaciju informacije i razvoj informacijske industrije.

„Potrebno je konstantno provjeravati i **vrednovati** mrežne izvore kako bi se izbjeglo korištenje nerelevantnih informacija.“

„Da bi bila relevantna informacija, između ostalog, mora biti **kvalitetna**.“

„Širenjem uporabe GPS (engl. Global Positioning System) tehnologija i razvojem geolokacijskoj marketinga porasla je **potražnja** za geografskim informacijama.“

„Informacijski marketing iznalazi najbolje metode i načine promocije koji povećavaju **prodaju** određenih informacija.“

„Informacijska tehnologija znatno **pojeftinjuje** cijenu jedne transakcije.“ (Saračević 2006; Lor - Britz 2007; Waltz 2003).

Ostali primjeri. Primjera je mnogo, a obuhvaćaju izraze usko vezane uz područje informacijskih djelatnosti i informacijske znanosti („stolno izdavaštvo“ kao izraz temeljen na konceptualnoj metafori RAČUNALO JE UREDSKI PROSTOR s podmetaforom RAČUNALO JE NAKLADNIČKA KUĆA ili izraz „rudarenje podataka“ koji podrazumijeva konceptualnu metaforu MREŽNI PROSTOR JE FIZIČKI PROSTOR s podmetaforom MREŽNI PROSTOR JE RUDNIK), izraze iz područja suvremene tehnologije i tehnoloških promjena (npr. „vizualizacija podataka“ kao izraz temeljen na konceptualnoj metafori RAZUMJETI/ZNATI JE VIDJETI ili izraz „umjetna inteligencija“ temeljen na konceptualnoj metafori SOFTVER JE RAZUMNO BIĆE) te izraze iz područja računalne tehnologije (npr. „virus“ i „bug“ podrazumijevaju konceptualnu metaforu INFORMACIJSKI SUSTAV JE ŽIVO BIĆE).

Tu su još i brojni primjeri vizualnih, orijentacijskih metafora koje se koriste u području mrežnog dizajna i vizualizacije podataka (UPRAVLJANJE (KONTROLA) JE GORE - CONTROL IS UP; VAŽNO JE VELIKO - IMPORTANT IS BIG; VIŠE JE GORE - MORE IS UP; GORE JE DOBRO - UP IS GOOD; SVIJETLO JE DOBRO - LIGHT IS GOOD; TAMNO JE LOŠE - DARK IS BAD).

3. Konceptualna integracija

3.1. Teorija konceptualne integracije

Iako učinkovita u području konvencionaliziranih konceptualnih metafora, u kojemu su analiza i rekonstruiranje postojećih preslikavanja dovoljni, teorija konceptualne metafore ne uspijeva objasniti sve figurativne izraze. Kada oni nisu motivirani konceptualnim metaforama, onda je u analizi izraza nemoguće primijeniti dvodomenski pristup. U jeziku suvremene znanosti neki izrazi figurativne naravi ne mogu se objasniti nijednom postojećom konceptualnom metaforom. Naime zbog dinamike i složenosti kognitivnih procesa koje ti izrazi iniciraju, isti ne podliježu analizi standardnog dvodomenskog modela. Stoga se u analizi novih metafora i njihova modeliranja u stvarnom vremenu najboljim rješenjem pokazala kombinacija tradicionalne konceptualne analize i konceptualne integracije.

U odnosu na nemogućnost da se svi figurativni izrazi objasne dvodomenskim pristupom, Fauconnier i Turner razvijaju višeprostorni model teorije konceptualne integracije čije se temeljne pretpostavke mogu pronaći u radovima Lakoffa i Johnsona i njihove teorije konceptualne metafore. Teoriju konceptualne integracije u svojim su radovima razvili Gilles Fauconnier i Mark Turner (Fauconnier – Turner 1996, 1998, 1999, 2002; Turner – Fauconnier 1995, 2000) oslanjajući se na Fauconnierovu teoriju mentalnih prostora (engl. *mental space theory*) (1985). „Mentalni su prostori konceptualni paketi konstruirani dok mislimo i govorimo, a s ciljem lokalnog razumijevanja i djelovanja.“ (Fauconnier – Turner 2002: 40). Mentalni prostori nastaju paralelno s procesom komunikacije kao promjenjivi i međusobno povezani konceptualni paketi kognitivnih procesa govora i mišljenja. Elementi dvaju ulaznih prostora analogijom konstruiraju jedan generički prostor s općim značajkama obaju ulaznih prostora. Na taj se način dobivaju četiri mentalna prostora prototipnih slučajeva teorije konceptualne integracije – ulazni prostori 1 i 2, generički i projekcijski prostor. Dva ulazna mentalna prostora sadrže ulazne informacije i s njima povezane elemente. Generički je prostor shematiziran u odnosu na ulazne prostore, a sadrži zajedničke elemente ulaznih prostora omogućujući tako preslikavanje elemenata iz jednog u drugi prostor (ako je riječ o konceptualnoj metafori) ili njihovo zajedničko sudjelovanje u projekcijskom prostoru, ključnom prostoru konceptualne integracije. Projekcijski je prostor središnji prostor koji sadrži elemente iz obaju ulaznih prostora međusobno povezane kroz manje ili više individualnu značenjsku i konceptualnu interpretaciju izraza i sadržaja, ali može sadržavati i elemente koji ne pripadaju nijednom od ulaznih prostora. Tu interpretaciju uvjetuju iskustvo i znanje osobe, kontekst i nesvjesno upotpunjavanje konceptualne strukture, što strukturu projekcijskog prostora čini dinamičnom. Osnovna je uloga mentalnih prostora povezivanje i homogeniziranje elemenata iz različitih konceptualnih domena stvaranjem struktura koje se mogu tumačiti ovisno o iskustvu i znanju te ovisno o predodžbenim shemama. To znači da struktura i oblik mentalnih prostora uvelike ovise o pozadinskim okvirima koji sadrže i aktiviraju različita opća i pojedinačna iskustva i znanja, a koja se povezuju s elementima mentalnih prostora upotpunjujući njihovu strukturu (Fauconnier – Turner 2000).

Tipizacija konceptualne integracije odnosi se na različite načine nastanka mentalnih prostora. Tako Fauconnier i Turner razlikuju četiri temeljna tipa:⁵

- jednostavne mreže – najjednostavniji tip konceptualne integracije sa strukturiranim elementima u ulaznom prostoru 1, nestrukturiranim elementima u ulaznom prostoru 2, projekcijskim prostorom s konceptualno integriranim ele-

5 Tu su još i tipovi konceptualne integracije s više od dva ulazna prostora, npr. žetelac – simbol smrti. Taj primjer podrazumijeva četiri prostora: prostor u kojem čovjek umire, prostor uzročne tautologije u kojem apstraktni pojam uzrokuje određeni događaj, prostor tipičnog primjera ubojice i prostor s žeteocima koji žanju (Fauconnier – Turner 2002: 291 – 292).

mentima dvaju ulaznih prostora i generičkim prostorom s izdvojenim sličnostima dvaju ulaznih prostora (primjer naziva za članove obitelji)

- zrcalne mreže - s dva jednako strukturirana ulazna prostora 'zrcalnih' smjerova, projekcijskim prostorom čiji okvir proizlazi iz strukture okvira dvaju ulaznih prostora i generičkim prostorom koji sadrži informacije zajedničke za oba ulazna prostora (primjer zagonetke o budističkom redovniku)
- jednookvirne mreže - s dva ulazna prostora koji odgovaraju izvorišnoj i ciljnoj domeni i projekcijskim prostorom čija je struktura u potpunosti izvedena iz strukture ulaznog prostora koji odgovara izvorišnoj domeni (primjer s dva boksača u ringu u kontekstu poslovne situacije)
- dvookvirne ili višeokvirne mreže - s dva ulazna prostora koji odgovaraju izvorišnoj i ciljnoj domeni i projekcijskim prostorom čija struktura proizlazi iz strukture obaju ulaznih prostora (strukturni okvir projekcijskog prostora ne može se svesti ni na jedan od okvira ulaznih prostora) - primjer ljutitog stanja 'pušenja' iz ušiju (Fauconnier i Turner 2002: 119 - 137).

Važnost teorije konceptualne integracije ogleda se u njezinu dvosmjernom karakteru i usmjerenosti na mentalne prostore, što omogućuje stvaranje novih značenja kao rezultata obaju ulaznih prostora te analizu metafora u stvarnom vremenu. Također, tom se teorijom mogu objasniti nove kategorije u znanosti, kao i neki percepcijski procesi, jer se objašnjenje novih značenja ne temelji na pojedinačnim domenama, već na njihovoj integraciji.

3.2. Konceptualna integracija u jeziku informacijskih znanosti

Kako teorija konceptualne integracije uvjetuje spoznajne i interpretacijske sposobnosti fenomena u informacijskim znanostima, pokazuju sljedeći primjeri.

Primjer 1. Konceptualna metafora RAČUNALO JE UREDSKI PROSTOR prikazana metodom dvookvirne mreže konceptualne integracije. Područje računalne, tj. informacijsko-komunikacijske tehnologije prostor je u kojem se, pod utjecajem tehničko-tehnološkog razvoja, neprestano stvaraju nove kategorije i procesi. Većina se navedenih primjera iz tog područja do sada relativno ustalila u jeziku i umu, pa su se njihova značenja već organizirala u pojedinačne konceptualne domene. Ipak, prije deset do dvadeset godina neki od tih primjera predstavljali su sasvim novo iskustvo koje se moglo, i još se uvijek može, objasniti metodom konceptualne integracije. Naprimjer konceptualna metafora RAČUNALO JE UREDSKI PROSTOR koja se javlja u primjeru stolnog izdavaštva može se tumačiti i metodom dvookvirne mreže konceptualne integracije. „U području tehnološkog dizajna računalna se sučelja aktiviraju, povezuju i preslikavaju i na razini konceptualnih struktura i na razini tjelesne aktivnosti. Najučinkovitije je sučelje radna površina...“ (Fauconnier i Turner 2002: 22).

Stolno izdavaštvo temelji se na uporabi softverskih ili mrežnih alata, a radna površina računala zamjenjuje uredski prostor nakladničke kuće. U tom primjeru radna površina računala postaje prvim ulaznim prostorom sa sljedećim elementima: slikovnim prikazom tekstova kao datoteka, pomicanjem mapa i datoteka po radnoj površini, otvaranjem mapa i datoteka dvostrukim *klikom* na njihov slikovni prikaz, uređivanjem tekstova naredbama *copy-paste*, *drag-and-drop*, *insert*, *undo* i dr. Uredski prostor nakladničke kuće drugi je ulazni prostor koji sadrži elemente fizičkog manipuliranja tekstovima (uređivanje, korektura, lektura itd.) i fizičkog opremanja tekstova (dizajn, tisak, uvez itd.). Opće značajke ulaznih prostora konstruiraju zamišljeni mentalni prostor u kojem se događa svaka promjena i manipuliranje sadržajima (mapama i datotekama), a iz kojeg se elementi međusobno povezani konceptualnom interpretacijom uredskog poslovanja i izdavaštva projiciraju nazad u projekcijski prostor. Zahvaljujući njemu, i unatoč činjenici da se na radnoj površini odigrava tek igra svjetlosti i sjene piksela, osoba ima dojam da se koristi određenim alatima, vrši određene aktivnosti i manipulira sadržajima na radnoj površini.

Primjer 2. Integracija mentalnih prostora u izrazu „računalni virus“. Iako koncept računala zaraženog virusom pretpostavlja konceptualnu metaforu RAČUNALO JE ŽIVO BIĆE, pa se stoga može zaraziti i liječiti, pojam virusa zasigurno se u vrijeme kada se pojavio tumačio metodom konceptualne integracije. Iako se ne radi o stvarnim oblicima života, računalni virusi otjelovljuju određene karakteristike jednostavnijih oblika života (bioloških virusa), a ako ga se tumači metodom konceptualne integracije, računalni virus obuhvaćao bi dva ulazna prostora – prostor bioloških virusa i prostor malicioznih računalnih programskih zapisa koje su izradili hakeri. U generičkom su se prostoru potom našli sljedeći elementi: virus je neželjeni entitet prisutan u organizmu/računalu, virus nije dio organizma/računala – on dolazi iz vanjske okoline i ulazi u sustav šireći zarazu, širenjem na druge dijelove organizma/računala virus ometa normalno funkcioniranje organizma/računala i nanosi mu štetu, a da bi se organizam/računalo riješio virusa, mora uzeti 'lijek'. U projekcijskom je prostoru tako nastao koncept računalnog virusa kao programa s gore navedenim karakteristikama, a koji otvara mjesto drugim konceptima iz tog područja računalstva poput „računalne sigurnosti“, „anitivirusnih programa“, „računalne dijagnostike“, „sigurnog rada na računalu“ itd.

Primjer 3. Umjetni život (engl. *artificial life*) i konceptualna integracija. Slično prethodnom primjeru, i izraz „umjetni život“ može se tumačiti teorijom konceptualne integracije. Konceptualna integracija tog izraza povezana je s idejom i projektom Richarda Dawkinsa koji je na računalu simulirao biološku evoluciju prema načelima prirodnog odabira.⁶ Prvi je prostor ove dvookvirne mreže računalo, a drugi je prostor

⁶ Ovaj primjer detaljnije opisuju Fauconnier i Turner u knjizi *The way we think: conceptual blending and the mind's hidden complexities*.

(biološki) život. U generičkom prostoru ti pojmovi dijele određenu strukturu - računalni programski kod i ljudski genetički kod te dinamiku razvoja, prijenosa informacija (nasljeđivanja) i razmjene informacija (metaboličkih procesa). Struktura projekcijskog prostora proizlazi iz strukture obaju ulaznih prostora stvarajući okvir umjetno oblikovanog života koji je nastao kao spoj genetskog koda i programskih algoritama i koji predstavlja nov tehnološki koncept utemeljen u analogiji života i bioloških procesa. Ovaj primjer dovodi do konceptualne promjene u shvaćanju života uopće dajući dublji uvid u njegovu prirodu, a na sličan bi se način mogao konceptualizirati i pojam umjetne inteligencije.

4. Znanstveni model

Modeli, kao proširene metafore, povećavaju broj metaforičkih pretpostavki utječući na razumijevanje i primjenu samog modela te čineći tako temelj za postavljanje znanstvenih teorija. Konceptualno neodvojiv od analogije, model je često dio znanstvenog diskursa, posebno u znanstvenim disciplinama kao što su fizika, kemija, biologija i tehničke znanosti. Mnogi su se autori bavili i bave se modelom kao vrstom metafore, a neki su od njih i Theodore Brown u knjizi *Making truth: metaphor in science* (2003) ili Dedre Gentner, Paul Thagard, Mary Gick i Keith Holyoak, koji se unutar teorije preslikavanja struktura (1983) bave pitanjem analogije i modela opisujući preslikavanje među domenama. Modeli u znanosti mogu biti matematički - simbolični modeli koji objašnjavaju značajke entiteta ili fenomena (matematička formula), analogni - vizualni supstituti pravog objekta, u 2D-prikazu (ilustracije, grafovi, tj. slikovni modeli) ili fizički - vizualni modeli u 3D-prikazu koji uključuju osjetilo vida i dodira. U svakom od navedenih slučajeva metafora omogućuje preslikavanje na određena obilježja fenomena koji predstavlja.

Razlika između modela i metafore počiva u činjenici da se priroda metafore realizira u jeziku, dok su modeli entiteti koji se mogu i jezično i prostorno-vremenski realizirati. Brown to objašnjava na sljedeći način: „Smatram da poimanje modela kao proširene metafore nije veliki problem. Model ima svoju strukturu i određeni broj elemenata koji se sustavno preslikavaju na ciljnu domenu. Nadalje, kao što dokazuje primjer metafore „kanala“, modeli potiču stvaranje metaforičkih pretpostavki.“ (Brown 2003: 25).

Dakle modeli mogu uvjetovati proces mišljenja o promatranom fenomenu proširujući njegovo (metaforičko) značenje. Oni nisu puki instrument razmišljanja već imaju produktivnu i generativnu funkciju. Ipak razmišljanje u okvirima modela treba 'kontrolirati' jer prevelika mentalna povezanost s modelom može spriječiti inovativne načine razmišljanja o fenomenu koji model predstavlja. Također, razlika između modela, teorija i metafora u znanosti može se definirati na sljedeći način: znanstvena teorija opisuje strukturu fenomena rabeći određenu simboličku predodžbu; model tu strukturu prenosi u 2D- ili 3D-prikaz vizualizirajući entitete i odnose među njima, a metafora u jezičnom kontekstu povezuje izvorišni i ciljni sustav preslikavajući obilježja

i odnose njihovih entiteta. Znanstvenici poput Rudolfa Carnapa (1959), Colina M. Turbaynea (1962) i Josepha R. Roycea (1978) kritiziraju znanstvene metafore tvrdeći da one svojim figurativnim izrazom 'skrivaju' pravo (stvarno) značenje, tj. istinu. Naprimjer Bohrov model atoma metaforički prikazan kao kruženje planeta oko Sunca može se smatrati nedostatnim jer ne govori ništa o matematičkim uvjetima koji trebaju biti ispunjeni (poput uvođenja Planckove konstante kao nužnog dijela Bohrovih matematičkih postulata) (Brown 2003). No uloga metafore nije razotkrivati istinito stanje stvari – to je uloga znanstvenih teorija, a metafora stvara slike. Riječima Nielsa Bohra, „kada su u pitanju atomi, jezik se može koristiti tek kao jezik poezije, jer cilj pjesnika nije opisati činjenice, nego stvarati slike”.⁷

4.1. Znanstveni model u jeziku informacijskih znanosti

Kako znanstveni model olakšava komunikaciju u informacijskim znanostima, prikazuju sljedeći primjeri.

Primjer 1. Relacijski model baze podataka. Relacijski model podataka prvi je definirao E. F. Codd krajem 60-ih godina prošlog stoljeća. Pomoću njega opisao je koncept modela podataka kao formalni sustav na najvišoj razini apstrakcije. Najveća je prednost relacijskog modela što u potpunosti počiva na matematičkoj teoriji relacijske algebre odnosno predikatnoj logici prvog reda. Tri su osnovna elementa tog modela: skup objekata (elemenata) baze podataka, skup procesa koji se mogu izvoditi nad objektima i skup pravila integriteta baze podataka. Modeli pojednostavljuju određeni fenomen i njegovo promatranje. Tako relacijski model pojednostavljuje i pojašnjava princip rada baze podataka. Relacijski model podataka jedan je od tri najčešća modela baza podataka, a temelji se na bazi podataka koja se sastoji od skupa pravokutnih tablica, tzv. relacija. Svaka relacija ima svoj naziv, po kojem se razlikuje od ostalih relacija u istoj bazi. Svaki stupac relacije sadrži vrijednost jednog atributa entiteta, a atribut također ima svoje ime po kojem ga se razlikuje od ostalih atributa u relaciji. Vrijednost jednog atributa jesu podatci istog tipa, dok je sama vrijednost jednostavna i jednostruka (ne može ju se dijeliti). Ponekad, ukoliko vrijednost atributa nije poznata, ona se ne mora upisati. Skup vrijednosti jednog atributa jest domena atributa. Jedan red relacije obično predstavlja jednu vrstu entiteta (ili bilježi vezu između dva ili više entiteta), a naziva se n-torka. U jednoj relaciji ne bi smjelo biti više istih n-torki. Tako se kod svake relacije može razlikovati stupanj relacije (broj atributa) i kardinalost relacije (broj n-torki). Građu relacije moguće je opisati shemom relacije koju čini ime relacije i popis atributa navedenih u zagradama. Naprimjer u bazi podataka knjižnice relacija „knjiga“ može biti jedna od relacija i unutar nje može biti nekoliko atributa (jedinstveni identifikator, autor, naslov, mjesto izdanja, nakladnik, godina izdanja,

broj stranica). Primjerice u bazi podataka knjižnice relacija „knjiga“ može biti jedna od relacija i unutar nje može biti nekoliko atributa (jedinstveni identifikator, autor, naslov, mjesto izdanja, nakladnik, godina izdanja i broj stranica).

Primjer 2. R-I-R-model (razlozi - interakcija - rezultati). Način rada informacijske službe/usluge može se predočiti R-I-R-modelom (razlozi - interakcija - rezultati). R-I-R-model u područje informacijskih znanosti uvode Tefko Saračević i Paul B. Kantor u radu *Studying the value of library and information services, part I - Establishing a theoretical framework* objavljenom 1997. godine u časopisu „Journal of the American society for Information science“. Model predstavlja tri dimenzije koje odražavaju vrijednosti korištenja neke informacijske usluge ili službe. Temelji se na A-C-A-modelu⁸ korištenja informacijama, također opisanom u navedenom radu, pomoću kojeg se može opisati vrijednost informacijske službe za korisnike, ali i za samu instituciju. Naravno, vrijednost informacijske usluge temelji se na njezinoj uporabnoj vrijednosti. R-I-R-model u obzir uzima korisnikovu percepciju informacije, uzajamno djelovanje korisnika i informacijske službe te iskoristivost dobivene informacije u odnosu na stvarne ciljeve. Dakle uključuje tri dimenzije: razlog za korištenje informacijskom uslugom ili službom (što korisnik želi), interakciju korisnika i usluga i službi tijekom njihova korištenja (korisnikova ocjena i odnos sa službom ili uslugom) i rezultate interakcije ili korištenja te njihovu vrijednost ili korist (relevantnost, korisnost, ispunjenje očekivanja).

Taj model, kao i A-C-A-model, olakšava pristup temeljnom pitanju - što (teorijski i praktično) čini vrijednost informacijskih usluga, a da bi korisnici bili zadovoljni? Ustvari, tim se modelom predočava princip korištenja informacijskim službama i uslugama, a njegova primjena olakšava vrednovanje istih.

Ostali primjeri. Navedenim se primjerima mogu još pribrojiti i primjeri poput opisanog A-C-A-modela korištenja informacijama, samonakladničkog modela nastalog kao rezultat tehnoloških promjena i inovativnog pristupa nakladničkom procesu, matematičkog (Shanon-Weaver) modela komunikacije koji je postao pretečom i paradigmom svih ostalih komunikacijskih modela i mnogih drugih.

8 A-C-A-model (pribavljanje - usvajanje - primjena) jest model korištenja informacijama koji se primjenjuje u informacijskim znanostima. Zastupljen je sljedećim fasetama: pribavljanje (koje predstavlja dolazak u informacijsku ustanovu i dobivanje informacije - knjige, članka), usvajanje (koje uključuje kognitivne procese spoznaje - npr. čitanje) i primjena (primjerice kada student na osnovi proučene literature piše određene misli izražene danim riječima). Iste su fasete uključene u procjenu vrijednosti informacije odnosno taj model, osim što predočava proces korištenja informacijom, pomaže i u njezinu vrednovanju.

5. Zaključak

Nemoguće je zamisliti znanstvenu pismenost bilo koje osobe bez njezine jezične pismenosti. Ukoliko želi biti spremna vidjeti svijet i pravilno shvatiti činjenice, entitete i fenomene koji su njegov sastavni dio, ali isto tako i biti spremna vidjeti budućnost, osoba se mora upoznati s jezikom znanstvene komunikacije i svim izražajnim i spoznajnim prednostima koje on nudi. Za jezik suvremene znanosti i uspješnu znanstvenu komunikaciju najbolji je izbor kombinacija konceptualne metafore, znanstvenog modela, analogija i zakona, ali i konceptualna integracija u slučajevima u kojima se događa dinamično povezivanje dviju domena, tj. u primjerima u kojima veze među domenama nisu toliko ustaljene. Koji će se pristup rabiti, ovisi o karakteristikama analiziranog znanstvenog fenomena. Ipak, ono što se sa sigurnošću može tvrditi jest da su metafore važan instrument znanstvene misli, bilo da se radi o njihovoj objasnidbenoj ulozi, njihovoj utkanosti u gotovo svako znanstveno istraživanje ili njihovoj sposobnosti preobrazbe i nadogradnje.⁹ Ono što je možda najveća prednost konceptualne metafore jest njezina sposobnost da povezivanjem izvorišne i ciljne domene pomakne spoznajne granice uma, pa se predmet ciljne domene tada može sagledati iz nove perspektive i pojmiti na nove načine.

Informacijske znanosti, iako razvijene 50-ih godina prošlog stoljeća, još uvijek se nalaze u procesu razvoja uvjetovanog neprekidnim razvojem i napretkom informacijsko-komunikacijske tehnologije i rastom informacija i znanja. Svi novi, apstraktni i nepoznati entiteti, pojave, procesi i strukture, koji su tu i koji će tek doći, mogu se prevesti na konkretan i poznat jezik povezujući ih s poznatim iskustvima i olakšavajući tako njihovo razumijevanje. Odabrani primjeri metaforičkih izraza u informacijskim znanostima pokazali su da se ta znanstvena disciplina uglavnom oslanja na konceptualnu metaforu i znanstveni model kao način prikaza novih znanstvenih fenomena. Većina je figurativnih izraza uvjetovana implementacijom suvremene digitalne tehnologije i promjenama koje ista uzrokuje u kontekstu informacijskog društva, a posebno onog njegova dijela koji se odnosi na interakciju čovjeka i tehnologije. Metafora je način oblikovanja većine naziva u informacijskim znanostima, što je vjerojatno usporedivo s metaforičkom uvjetovanošću računalnog i informacijsko-tehnološkog nazivlja u engleskom jeziku koje vrlo lako prodire u hrvatski. Također, u odabranim je primjerima vrlo mali broj onih u kojima se konceptualizira apstraktna kategorija vremena, u odnosu na one u kojima se konceptualiziraju stanje i prostor. Uzrok tomu vjerojatno leži u činjenici da se u informacijskim znanostima vrijeme ne uzima kao ključan čimbenik, već se većinom posredno uključuje u određeni izraz (*streaming* informacija kao trenutni događaj, paralelna obradba podataka kao primjer paralelnog poimanja vremena, serijska obradba podataka kao primjer serijskog poimanja vremena itd.). Nasuprot tomu, kategorije prostora i stanja ključne su za opis novih fenomena, kao

⁹ S porastom količine informacija o određenom pitanju koje se metaforički prikazuje, i sama metafora može doživjeti promjene i proširenja.

što su pojava novih oblika inteligencije i 'života', novih stanja svijesti, ali i odnosa, interakcije i procesa koji se događaju u određenom prostoru, bio on stvaran ili umjetan.

Odabrani metaforički izrazi i modeli predstavljaju tek dio jezika informacijskih znanosti ocrtavajući obrise diskursa informacijskih znanosti i razotkrivajući strukture jezično kodiranog znanja.

Literatura

- Afrić, V. 2002. „Informacijske tehnologije i društvo“. U Zbornik radova „Težakovi dani“, ur. Tkalac, S. - Lasić-Lazić J., 7 - 19. Zagreb: Filozofski fakultet, Zavod za informacijske studije Odsjeka za informacijske znanosti.
- Aparac-Jelušić, T. 1993. *Teorijske osnove knjižnične znanosti*. Zagreb: Filozofski fakultet, Zavod za informacijske studije Odsjeka za informacijske znanosti.
- Barcelona, A. 2000. *On the plausibility of claiming a metonymic motivation for conceptual metaphor. Metaphor and metonymy at the crossroads: a cognitive perspective*. Berlin - New York: Mouton de Gruyter.
- Belaj, B. 2005. „O kognitivnom statusu mentalnih prostora i o nekim tipovima metonimije u okviru teorije konceptualne integracije“. *Jezikoslovlje* 6, 2: 119 - 144.
- Belkin, N. J. - Robertson, S. E. 1976. „Information science and the phenomenon of information.“ *Journal of the American Society for Information Science* 27, 4: 197 - 204.
- Boroditsky, L. - Ramscar, M. - Frank, M. C. 2002. „The roles of body and mind in abstract thought“. *Psychological Science* 13, 2: 185 - 189.
- Brown, P. 2003. *Information architecture with XML: a management strategy*. Chichester: John Wiley & Sons Ltd.
- Brown, T. L. 2003. *Making truth: metaphor in science*. Urbana - Chicago: University of Illinois Press.
- Diez Velasco, O. I. 2001. „Metaphor, metonymy and image-schemas: an analysis of conceptual interaction patterns“. *Journal of English studies* 3, 2: 47 - 63.
- Evans, V. - Chilton, P. 2010. *Language, cognition and space: the state of the art and new directions*. London: Equinox Publishing Company.
- Fauconnier, G. (1994). *Mental spaces*. New York: Cambridge University Press.
- Fauconnier, G. - Turner, M. 2000. „Compression and global insight“. *Cognitive Linguistics* 11: 283 - 304.
- Fauconnier, G. - Turner, M. 2002. *The way we think: conceptual blending and the mind's hidden complexities*. New York: Basic Books.

- Gibbs, R. W. Jr. 2008. *The Cambridge handbook of metaphor and thought*. Cambridge: Cambridge University Press.
- Gibbs, R. W. Jr. – Costa Lima, P. L. – Francozo, E. 2004. „Metaphor is grounded in embodied experience“. *Journal of pragmatics* 36: 1189 – 1210.
- Goatly, A. 2000. *The language of metaphors*. London: Routledge.
- Grady, J. E. 1997. „Theories are buildings: revisited“. *Cognitive linguistics* 8, 4: 267 – 290.
- Grady, J. E. – Oakley, T. – Coulson, S. 1999. „Blending and metaphor. Metaphor in cognitive linguistics“, <http://www.cogsci.ucsd.edu/~coulson/Papers/grady-etal.pdf> (15. 04. 2012.)
- IEEE Xplore Digital Library, <http://ieeexplore.ieee.org/Xplore/guesthome.jsp>; IEEE Spectrum: Inside Technology
- Katz, A. N. 1998. *Figurative Language and Thought*. New York: Oxford University Press.
- Kövecses, Z. 2002. *The scope of metaphor. Metaphor and metonymy at the crossroads: a cognitive perspective*. Berlin – New York: Mouton de Gruyter.
- Kövecses, Z. 2003. *Metaphor and emotion: language, culture and body in human feeling*. Cambridge: Cambridge University Press.
- Kövecses, Z. 2005. *Metaphor in culture: universality and variation*. New York: Cambridge University Press.
- Lakoff, G. 1987a. „Image metaphors“. *Metaphor and symbolic activity* 2, 3: 219 – 222.
- Lakoff, G. 1987b. *Women, fire and dangerous things: what categories reveal about the mind*. Chicago – London: The University of Chicago Press.
- Lakoff, G. 1987c. „The death of dead metaphor“. *Metaphor and symbolic activity* 2, 2: 143 – 147.
- Lakoff, G. 1990. „The invariance hypothesis: is abstract reason based on imageschemas?“ *Cognitive linguistics* 1, 1: 39 – 74.
- Lakoff, G. – Johnson, M. 2003. *Metaphors we live by*. Chicago – London: The University of Chicago Press.
- Lakoff, G. – Johnson, M. 1999. *Philosophy in the flesh: the embodied mind and its challenge to western thought*. New York: Basic books.
- Lessig, L. 2004a. *Free culture: how big media uses technology and the law to lock down culture and control creativity*. New York: The Penguin Press.
- Lessig, L. 2004b. *Kod i drugi zakoni kiberprostora*. Zagreb: Multimedijalni institut.
- Lor, P. J. – Britz J. J. 2007. „Is a knowledge society possible without freedom of access to information?“ *Journal of information science* 33: 387 – 397.

- National Science Foundation 2008. Science and Technology: Public Attitudes and Understanding, Information Sources, Interest, and Perceived Knowledge. <http://www.nsf.gov/statistics/seind04/c7/c7s1.htm> (05. 12. 2012).
- Pelc, M. 2002. *Pismo - knjiga - slika: uvod u povijest informacijske kulture*. Zagreb: Golden marketing.
- Peters, H. P. 2007. „The science - media interface: interactions of scientists and journalists“. *Communicating European Research* 2005: 51 - 57.
- Reiss, E. L. 2000. *Practical information architecture: a hands-on approach to structuring successful websites*. London: Pearson Education Limited.
- Ruiz de Mendoza, F. J. 1997. „Cognitive and pragmatic aspects of metonymy“. *Cuadernos de Filología Inglesa* 6, 2: 161 - 178.
- Saračević, T. 2006. *Prilozi utemeljenju informacijske znanosti*. Osijek: Filozofski fakultet.
- Stanojević, M.- M. 2009. „Konceptualna metafora u kognitivnoj lingvistici: pregled pojmova“. *Suvremena lingvistika* 68, 2: 339 - 371.
- Stipčević, A. 2006. *Povijest knjige*. Zagreb: Matica hrvatska.
- Stojanovski, J. 2006. *Online baze podataka: priručnik za pretraživanje*. Zagreb: CARNet.
- Turner, M. - Fauconnier, G. 2000. *Metaphor, metonymy and binding. Metaphor and metonymy at the crossroads: a cognitive perspective*. Berlin - New York: Mouton de Gruyter.
- Waltz, S. B. 2003. „Everything new is old again: technology and the mistaken future“. *Bulletin of science technology society* 23: 376 - 381.

Summary

Language of Scientific Communication: the Most Frequent Conceptual Mechanisms in Observing and Describing Scientific Phenomena in Information Science

The aim of the paper is to analyze and to present the most frequent conceptual mechanisms in observing and describing scientific phenomena which allow a successful and efficient exchange of information on the level of communication between the scientific community and the "audience", and also on the level of communication within the scientific community itself, within the field of information science.

Application of conceptual mechanisms in the language of information science is presented through the examples of often, almost daily used terms, such as database, gadget race, information architecture, intellectual property, print revolution, com-

puter virus, artificial life, etc. The observing and describing of these terms has been followed, both in popular discourse (such as on various web pages), as well as in available scientific and professional literature.

The work is comprised of four parts. After the basic introductory part on the language of scientific communication, follows the presentation of the conceptual metaphor theory, conceptual integration theory and scientific model. Each conceptual mechanism is followed by the analysis of specific examples from the language of the information science.

Taking into consideration that the area of information science is under a constant influence of technological changes and development of modern information communication technology, new and different phenomena are often observed, and they require a new thinking framework in the process of observation, as well as the new ways of language articulation during the process of their description and communication to the scientific and non scientific audience. The fundamental contribution of the paper is the display and analysis of few examples of the observed new thought patterns and new ways of language articulation in popular and scientific discourse of the information science language.

KEYWORDS: language of scientific communication, information science, cognitive linguistics, conceptualization, conceptual metaphor theory, conceptual integration theory, scientific model.